

PAPER DETAILS

TITLE: Arazi Kullanım Siniflari İçin Farkli Kontrollü Siniflandirma Algoritmalarinin Karsilastirilmesi

AUTHORS: Sinan Bulut,Alkan Günlü

PAGES: 528-535

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/273228>

Arazi Kullanım Sınıfları İçin Farklı Kontrollü Sınıflandırma Algoritmalarının Karşılaştırılması

*Sinan BULUT¹, Alkan GÜNLÜ¹

¹Çankırı Karatekin Üniversitesi, Orman Fakültesi, Orman Mühendisliği Bölümü, 18200, ÇANKIRI

*Sorumlu yazar: sbulut@karatekin.edu.tr

Geliş Tarihi: 01.07.2016

Özet

Bu çalışmanın amacı, Landsat 8 uydu görüntüsü kullanarak arazi kullanım sınıflarını farklı kontrollü sınıflandırma algoritmaları ile sınıflandırmak ve en uygun tekniği ortaya koymaktır. Bu amaçla, en yüksek olasılık (maksimum likelihood) ile destek vektör makineleri (DVM) için yaygın bir şekilde kullanılan doğrusal, polinom, radyal ve sigmoid kernel fonksiyonları kullanılmıştır. En iyi sonucu veren en yüksek olasılık metodu ile DVM polinom fonksiyonu çıktıları karşılaştırılmıştır. En yüksek olasılık metodu için kappa değeri ve genel sınıflandırma başarısı sırasıyla 0.81 ve %85'dir. DVM polinom fonksiyonu için ise bu değerler sırasıyla 0.79 ve %84'tür. Ayrıca, her iki yöntemle sınıflandırılmış arazi kullanım sınıflarının konumsal analizi Coğrafi Bilgi Sistemleri kullanılarak yapılmıştır. Konumsal analiz sonuçlarına göre en yüksek olasılık metodu kullanılarak toplam alanın %47.5'i, DVM polinom fonksiyonu ile %43.3'ü doğru bir şekilde sınıflandırılmıştır.

Anahtar Kelimeler: Arazi kullanım sınıfları, En yüksek olasılık, Destek vektör makineleri, Landsat 8 uydu görüntüsü

Comparison of Different Supervised Classification Algorithms for Land Use Classes

Abstract

The aim of this study was to classify land use classes using Landsat 8 satellite image with different supervised classification algorithms and demonstrate the most proper technique. For this purpose, the highest probability (maximum likelihood) classification method and linear, polynomial, radial and sigmoid kernel functions for support vector machines (SVM) were used. The SVM method polynomial function and the maximum likelihood method which give better results were compared. The result showed that the maximum likelihood method was estimated with a 0.81 kappa statistic and 85% overall accuracy assessments, respectively. The SVM polynomial function for these values was 0.79 and 84%. Spatial analysis of land use classes that were classified using both methods was also made by Geographical Information System. According to the spatial accuracy assessment results, 47.5% and 43.3% of total area were classified accurately by the maximum likelihood method and the SVM method, respectively.

Keywords: Land use classes, Maximum likelihood, Support Vector Machines, Landsat 8 satellite image

Giriş

Gelişen teknoloji, uydu sistemleri ve uygulamaya aktarılan yeni metotlar gün geçtikçe farklı ve derin boyutlar kazanmaktadır. Günümüzde uzaktan algılamanın konu olmadığı bilim dalları pek azdır. Özellikle ormancılık alanında yoğun bir kullanım alanı bulan uzaktan algılama sayesinde uydu görüntülerinin sınıflandırılması, meşcere parametrelerinin tahmini ve arazi yapılarının farklı formatlarda haritalara dökülmesi ile büyük ölçekli alanlar hakkında kolay bir şekilde ön bilgi elde edilebilmektedir. Yapılan bu işlemler için kullanılabilecek farklı teknikler bulunmaktadır. Uydu görüntülerinin sınıflandırılmasında kullanılacak pek çok

algoritma mevcuttur. Destek vektör makineleri (DVM), en yüksek olasılık, en yakın mesafe, mahalanobis sınıflandırıcısı, yapay sinir ağları ve karar ağaçları bunlardan bazılarıdır (Otukey ve Blaschke, 2010; Srivastava ve ark., 2012; Taati ve ark., 2014; Üstüner ve ark., 2015; Kulkarni ve Lowe, 2016). Literatürde yapılan çalışmalar incelendiğinde, farklı sınıflandırma algoritmaları kullanılarak yapılmış pek çok araştırma mevcuttur.

Huang ve ark. (2002) tarafından yapılan çalışmada, arazi örtü sınıfları MODIS uydu görüntüsü kullanılarak sınıflandırılmıştır. Bu işlem için DVM, en yüksek olasılık, yapay sinir ağları ve karar ağaçları yöntemleri kullanılmıştır. En yüksek başarı DVM

yöntemi ile elde edilmiş ve ilgili metotların genel sınıflandırma başarıları sırasıyla %75.62, %71.76, %74.02 ve %73.31'dir. Kavzoğlu ve Çölkesen (2010) yaptıkları çalışmada, Landsat ETM+ uydu görüntüsü kullanarak 6 farklı arazi örtü tipi için sınıflandırma işlemi gerçekleştirmişlerdir. Sınıflandırmada, en yüksek olasılık ve DVM'nin polinom, normalleştirilmiş polinom, radyal ve Pearson VII fonksiyonları kullanılmıştır. En iyi sonucu DVM'nin Pearson VII fonksiyonu vermiştir (kappa değeri=0.94, genel sınıflandırma başarıları=%94.83). Çölkesen ve ark. (2016) tarafından yapılan başka bir çalışmada, arazi kullanım sınıflarının ayırt edilmesine yönelik sınıflandırma yapılmış ve sınıflandırma sonucunda %90.46'lık bir genel sınıflandırma başarıları elde edilmiştir.

Bu çalışmada, Landsat 8 uydu görüntüsü kullanılarak, kontrollü sınıflandırma algoritmalarından en yüksek olasılık metodu ve DVM'nin doğrusal, polinom, radyal ve sigmoid kernel fonksiyonları kullanılarak


arazi kullanım sınıfları belirlenmeye çalışılmıştır. Yapılan sınıflandırma işlemi sonucunda performans ölçütleri ortaya konulmuş, en yüksek olasılık metodu ile en iyi sonucu veren DVM fonksiyonuna ilişkin konumsal başarı analizi yapılmış ve karşılaştırılmıştır.

Materyal ve Metot

Çalışmada, 2013 yılında yapılan envanter çalışması sonucunda üretilen meşcere haritası ve 01.09.2015 Landsat 8 uydu görüntüsü materyal olarak kullanılmıştır.

Çalışma alanı

Bu çalışma, Kastamonu Orman Bölge Müdürlüğü, Samatlar Orman İşletme Müdürlüğü'ne bağlı Kartalsuyu Orman İşletme Şefliği için gerçekleştirilmiştir (Şekil 1). Planlama biriminin toplam alanı 16084.9 ha'dır. Bu alanın 11406.1 ha'lık bölümü (%70.8) ormanlarla kaplıdır ve önemli bir bölümü (%39.5) ibreli ağaçlardan oluşmaktadır (Anonim 2014).



Şekil 1. Kartalsuyu Orman İşletme Şefliği coğrafi konumu

Kartalsuyu Orman İşletme Şefliği, coğrafi olarak Batı Karadeniz bölgesinde, Kastamonu ilinin Araç ilçesi sınırları içerisinde yer almaktadır. Bölgenin en yüksek noktası Görlez mevkii olup rakımı 1744 metredir. En düşük yükseltisi ise 415 metre ile planlama biriminin güney sınırında yer almaktadır. İlgili planlama birimi Ekvator'a göre

41° 03' 07" – 41° 11' 46" kuzey enlemleri ile Greenwich'e göre 32° 55' 53" – 33° 13' 02" doğu boylamları arasındadır (Anonim 2014).

Görüntü sınıflandırma

Bir uydu görüntüsünün sınıflandırılmasında kullanılabilecek çok sayıda yazılım ve yöntem bulunmaktadır. Bu çalışmada yapılan sınıflandırma işlemleri ENVI 5.2 yazılımı ile gerçekleştirilmiştir. Kullanılan metotlar ise en yüksek olasılık ve destek vektör makinelerinin (DVM) doğrusal, polinom, radyal ve sigmoid kernel fonksiyonlarıdır. Sınıflandırma işleminde referans veri olarak meşcere haritası kullanılmıştır. Burada referans veri olarak kullanılan meşcere haritası doğru olarak kabul edilmiştir. Meşcere haritasından yararlanılarak, arazi kullanım sınıfları ibrelili orman, yapraklı orman, karışık orman, bozuk orman ve diğer alanlar (Su, İs, Z, OT, Kum) olmak üzere beş farklı sınıfta değerlendirilmiştir. Her bir arazi kullanım sınıfı için, Landsat 8 uydu görüntüsü üzerinden 10 adet eğitim alanı alınmıştır. Eğitim alanlarının homojen ve yeterli büyüklükte olmasına özen gösterilmiştir. Bu metotların karşılaştırılmasında denklik olması için bütün sınıflandırma işlemlerinde aynı eğitim alanları kullanılmıştır.

En yüksek olasılık metodu

En yüksek olasılık metodu, uydu görüntülerinin sınıflandırılmasında yaygın kullanımı olan bir kontrollü sınıflandırma tekniğidir. Bu yöntem istatistiksel tabanlı bir sınıflandırma algoritması olup, ortalama değerler yanında, varyans ve kovaryans değerlerini de dikkate almaktadır. Bu değerlendirme aşamasında sınıf kontrol kümelerini oluşturan verilerin normal dağılıma sahip olduğu varsayılmaktadır. Sınıflandırma aşamasında olasılık yoğunluk fonksiyonları hesaplanmaktadır (1) ve sınıflandırılacak pikseller üyelik olasılığı en yüksek olan sınıflara atanmaktadır. Eğer pikseller için hesaplanan sınıflara ait olma olasılık değerleri, öncesinde belirlenen eşik değerinin altında ise ilgili pikseller belirsiz olarak sınıflandırılmaktadır (Myung, 2003;


Çölkesen, 2009; Günlü, 2012; Topaloğlu ve ark., 2016).

$$P(x) = \ln(a_c) - [0.5x\ln(|S_x|)] - [0.5x(x - M_C)^T S_x^{-1} x(x - M_C)] \quad (1)$$

Eşitlikte, P olasılık değeri, C örnek bir sınıfı, x aday pikselin ölçüm vektörü, M sınıfın ortalaması, a aday pikselin sınıfa ait olma yüzdesi ve S_x varyans-kovaryans matrisidir.

Destek vektör makineleri

Kontrollü sınıflandırma algoritmalarından olan DVM, yapısal risk minimizasyonu prensibine ve istatistiksel öğrenme teorisine dayanmaktadır. DVM başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırma problemini çözmek için geliştirilmiştir. DVM’de amaç, iki sınıfı birbirinden ayırabilen en uygun hiper düzlemin elde edilmesidir (Şekil 2).



Şekil 2. İki sınıflı bir problemde en uygun hiper düzlem, sınır ve destek vektörleri

Hiper düzlemin sınır genişliğini sonlandıran noktalara destek vektörleri adı verilmektedir. Elde edilen hiper düzlem sayesinde destek vektörleri arasındaki uzaklık maksimize edilmekte ve en uygun karar fonksiyonu oluşturulmaktadır (Kavzoğlu ve Çölkesen, 2010; Hsu ve ark., 2010; Ayhan ve Erdoğan, 2014; Kulkarni ve Lowe, 2016).

Tablo 1. Kullanılan kernel fonksiyonlarının matematiksel gösterimi ve en iyi sonucu veren parametre değerleri

Kernel Fonksiyonu	Matematiksel Gösterimi	Parametre ve Kullanılan Değerler
-------------------	------------------------	----------------------------------

		*p	g	r	d
Doğrusal Fonksiyon	$K(x_i, x_j) = x_i^T x_j$	175			
Radyal Fonksiyon	$K(x_i, x_j) = \exp(-g\ x_i - x_j\ ^2), g > 0$	200	0.125		
Polinom Fonksiyon	$K(x_i, x_j) = (g x_i^T x_j + r)^d, g > 0$	150	0.125	1	5
Sigmoid Fonksiyon	$K(x_i, x_j) = \tanh(g x_i^T x_j + r)$	150	0.125	1	

*isteğe bağlı, p: düzenleme parametresi (>0.01), g: gama (>0.01), r: hata (1), d: polinom derecesi (1-6)


DVM kullanılarak yapılacak bir sınıflandırma işleminde farklı kernel fonksiyonları kullanılmaktadır. Her bir kernel fonksiyonu için uygulayıcı tarafından belirlenmesi gereken farklı parametreler bulunmaktadır (Tablo 1). Çalışmada doğrusal, polinom, radyal ve sigmoid kernel fonksiyonları için bu parametreler farklı değerler kullanılarak beşer kez denenmiştir (Şekil 3). Kullanılan 5 farklı kontrollü sınıflandırma yöntemi, yaygın bir kullanıma sahip olan genel sınıflandırma başarısı ve kappa değeri kullanılarak değerlendirilmiştir. Bunun sonucunda ilgili yöntemlerden en yüksek kappa değerine ve genel sınıflandırma başarısına sahip en iyi iki metot için konumsal başarı analizi yapılmıştır. Bunun için iki metodun uygulaması sonucunda üretilen sınıflandırma haritaları vektör veriye çevrilmiştir. Elde edilen vektör katmanları ile meşcere haritası ArcGIS 10.0 yazılımı ile karşılaştırılmıştır. Çakıştırma sonucunda konumsal olarak toplam alanın ne kadarının doğru bir şekilde sınıflandırıldığı ortaya konulmuştur.

Bulgular ve Tartışma

Bu çalışmada, arazi kullanım sınıfları için yapılan sınıflandırma işleminde, en yüksek olasılık metodu için kappa değeri 0.81 ve genel sınıflandırma başarısı %85'tir. DVM doğrusal fonksiyon kullanılarak elde edilen kappa değeri ve genel sınıflandırma başarısı 0.77 ve %81'dir. Bu değerler sırasıyla DVM radyal fonksiyon için 0.75 ve %80, DVM polinom fonksiyon için 0.79 ve %84, DVM radyal fonksiyon için 0.63 ve %71'dir. DVM'nin farklı kernel fonksiyonları için elde edilen bu sonuçlar, yapılan farklı

sınıflandırma işlemleri arasından elde edilen en iyi sonuçlardır.

Kulkarni ve Lowe (2016) tarafından yapılan bir çalışmada Landsat 8 uydu görüntüsü kullanılarak arazi örtüsü sınıflaması yapılmıştır. DVM metodu (kappa değeri=0.99, genel sınıflandırma başarısı=%99) en yüksek olasılık metoduna (kappa değeri=0.93, genel sınıflandırma başarısı=%90) göre daha iyi performans göstermiştir. Topaloğlu ve ark., (2016) Landsat 8 uydu görüntüsüne ek olarak Sentinel 2 uydu görüntüsü de kullanarak arazi örtü sınıflaması yapmışlardır. En iyi sonuç Sentinel 2 uydu görüntüsü ile DVM metodu kullanılarak elde edilmiştir (kappa değeri=0.82, genel sınıflandırma başarısı=%84). En düşük sonuç ise Landsat 8 uydu görüntüsü ile en yüksek olasılık metodu kullanılarak elde edilmiştir (kappa değeri=0.66, genel sınıflandırma başarısı=%71). Üstüner ve ark., (2015) RapidEye uydu görüntüsü kullanarak yaptıkları çalışmada en yüksek performansı DVM polinom fonksiyonu ile elde etmişlerdir. En yüksek olasılık metodu, DVM polinom, doğrusal, radyal ve sigmoid fonksiyonları ile sırasıyla 0.7968, 0.8411, 0.8223, 0.8222 ve 0.8209 kappa değerleri elde edilmiştir. Genel sınıflandırma başarıları ise sırasıyla %81.64, %85.63, %83.94, %83.94 ve %83.82'dir. Taati ve ark., (2014) yaptıkları çalışmada Landsat 5 uydu görüntüsü kullanarak DVM metodu ile 0.82'lik kappa değeri ve %86.67'lik genel sınıflandırma başarısı, en yüksek olasılık metodu ile de 0.72'lik kappa ve %80'lik genel sınıflandırma başarısı elde etmişlerdir.



Şekil 3. DVM ile elde edilen farklı fonksiyonlara ait kappa değerleri

Bu çalışmada uygulanan farklı kontrollü sınıflandırma metotları sonucunda en iyi performansı gösteren metotlar, en yüksek olasılık ve DVM polinom fonksiyonudur. Çalışmada, bu iki metot için konumsal başarı analizi yapılmış, sonuçlar tablo ve haritalar yardımıyla ortaya konulmuştur (Tablo 2-3, Şekil 4-5-6). Buna göre ibrelî ormanın meşcere haritasında alan miktarı 6359.63 ha'dır. En yüksek olasılık metodu ile yapılan sınıflandırma sonucunda elde edilen görüntü

üzerinde ibrelî ormanların alan miktarı 2058.28 ha olup bu alanın 1954.02 ha'ı konumsal olarak doğru bir şekilde sınıflandırılmıştır. DVM polinom fonksiyonu ile yapılan sınıflandırma işlemi ise ibrelî ormanlar 2011.02 ha alan kaplamakta ve bu alanın 1895.93 ha'ı doğru sınıflandırılmıştır. Bu iki metot için ibrelî orman sınıfının konumsal sınıflandırma başarıları oldukça benzerdir (%94.9 ve %94.3).

Tablo 2. En yüksek olasılık metodu ile meşcere tipi haritası ve Landsat 8 uydu görüntüsünden elde edilen arazi kullanım sınıflarının konumsal analiz sonuçları

Arazi Kullanım Sınıfları	Meşcere Tipi Haritası		Landsat 8 Uydu Görüntüsü		Farklar (+/-)	Sınıflandırmanın Konumsal Başarısı	
	ha	%	ha	%		ha	%
İbrelî Orman	6359.63	39.5	2058.28	12.8	4301.35	1954.02	94.9
Yapraklı Orman	1820.56	11.3	2057.75	12.8	-237.19	724.61	35.2
Karışık Orman	1314.99	8.1	4344.35	27.0	-3029.66	712.21	16.4
Bozuk Orman	1910.68	11.9	3560.67	22.1	-1649.99	1079.70	30.3
Diğer Alanlar	4678.42	29.2	4063.23	25.3	615.19	3164.89	77.9
Toplam	16084.28	100.0	16084.28	100		7635.43	47.5

Tablo 3. DVM polinom fonksiyonu ile meşcere tipi haritası ve Landsat 8 uydu görüntüsünden elde edilen arazi kullanım sınıflarının konumsal analiz sonuçları


Arazi Kullanım Sınıfları	Meşcere Tipi Haritası		Landsat 8 Uydu Görüntüsü		Farklar (+/-)	Sınıflandırmanın Konumsal Başarısı	
	ha	%	ha	%		ha	%
İbrelî Orman	6359.63	39.5	2011.02	12.5	4348.61	1895.93	94.3
Yapraklı Orman	1820.56	11.3	3558.19	22.1	-1737.63	783.04	22.0
Karışık Orman	1314.99	8.1	3445.68	21.4	-2130.69	624.24	18.1
Bozuk Orman	1910.68	11.9	3669.74	22.8	-1759.06	985.53	26.9
Diğer Alanlar	4678.42	29.2	3399.65	21.2	1278.77	2681.72	78.9
Toplam	16084.28	100.0	16084.28	100		6970.46	43.3

Yapraklı orman sınıfı için en yüksek olasılık metodu ile elde edilen görüntüde alan miktarı 2057.75 ha'dır ve bu alanın 724.61 ha'ı doğru olarak sınıflandırılmıştır. Bu sınıf için elde edilen konumsal sınıflandırma başarısı %35.2'dir. DVM polinom fonksiyonu için ise oluşturulan 3558.19 ha'lık yapraklı orman sınıfından 783.04 ha'lık kısmı doğru sınıflandırılmıştır. Bu durumda elde edilen konumsal sınıflandırma başarısı %22'dir. DVM polinom fonksiyonu daha fazla miktarda alanı doğru sınıflandırmıştır. Fakat bunu sınıf alanına oranladığımızda sınıflandırma başarısı DVM metodu için daha düşük çıkmaktadır.


Karşılaştırılan iki metot için konumsal sınıflandırma başarısına ait en yüksek fark yapraklı orman sınıfı için elde edilmiştir (%13.2). Karışık orman ve diğer alanlar sınıfı için DVM polinom fonksiyonu daha başarılı bulunmuştur. Diğer sınıflar için en yüksek olasılık metodu daha başarılı olmakla birlikte genel olarak elde edilen konumsal başarı oranları oldukça benzerdir. En düşük başarı, en yüksek olasılık metodu ile %16.4, DVM

polinom fonksiyonu ile %18.1 konumsal sınıflandırma başarısı olmak üzere karışık orman sınıfı için elde edilmiştir. En yüksek başarı, en yüksek olasılık metodu ile %94.9, DVM polinom fonksiyonu ile %94.3 olmak üzere ibrelili orman sınıfı için elde edilmiştir. Genel başarı yüzdesine bakıldığında ise en yüksek olasılık metodu konumsal olarak alanın %47.5'ini, DVM polinom fonksiyonu ise %43.3'ünü doğru bir şekilde sınıflandırmıştır.


Araştırma konusu ile ilgili olarak yapılan benzer çalışmalar incelendiğinde; Günlü ve ark., (2008) Landsat 7 ETM uydu görüntüsü kullanarak arazi örtü tipini sınıflandırmışlar ve %61.7'lik konumsal sınıflandırma başarısı elde etmişlerdir. Günlü ve ark., (2011) yaptıkları farklı bir çalışmada konumsal analiz sonuçlarına göre arazi kullanım sınıfları için %45.5 oranında sınıflandırma başarısı elde etmişlerdir. Günlü (2012) tarafından yapılan başka bir çalışmada ise arazi kullanım sınıfları için konumsal sınıflandırma başarısı %58.6 bulunmuştur.



Şekil 4. Arazi kullanım sınıfları a) meşcere tipi haritası b) Landsat8 uydu görüntüsü (en yüksek olasılık metodu)



Şekil 5. Arazi kullanım sınıfları a) meşcere tipi haritası b) Landsat8 uydu görüntüsü (DVM polinom fonksiyonu)



Şekil 6. Konumsal analiz başarı haritası a) en yüksek olasılık metodu b) DVM polinom fonksiyonu

Sonuç

Bu çalışmada en yüksek olasılık ve destek vektör makinelerinin (DVM) doğrusal, polinom, radyal ve sigmoid kernel fonksiyonları kullanılarak kontrollü sınıflandırma işlemi gerçekleştirilmiştir. Yapılan sınıflandırma sonucunda bütün metotlar kappa değeri ve genel sınıflandırma başarısı baz alınarak değerlendirilmiş ve en iyi sonuç veren en yüksek olasılık metodu ve DVM polinom fonksiyonu için konumsal başarı analizi yapılarak değerlendirilmiştir.

Elde edilen sonuçlara göre en yüksek olasılık metodu kappa değeri, genel sınıflandırma başarısı, konumsal başarı ve kullanım kolaylığı açısından daha avantajlı görülmüştür. Fakat yapılan farklı çalışmalara bakıldığında DVM ile yapılan sınıflandırma işlemlerinde göz ardı edilmeyecek seviyede iyi sonuçlar elde edilmektedir. Bundan dolayı bu tür çalışmaların yaygınlaştırılması, daha yüksek çözünürlükte uydu görüntülerinin kullanılması, özellikle sınıflandırma işlemlerinde eğitim alanlarının daha fazla sayıda ve hassas bir şekilde alınması uygulanan metotların performansı açısından daha doğru bilgi edinilmesini sağlayacaktır.

Teşekkür

Bu çalışmada kullanılan meşcere haritalarının temini için Orman Genel Müdürlüğü, Orman İdaresi ve Planlama Daire Başkanlığına teşekkür ederiz.

Kaynaklar

Anonim 2014. Kastamonu Orman Bölge Müdürlüğü, Samatlar Orman İşletme Müdürlüğü, Kartalsuyu Orman İşletme Şefliği fonksiyonel orman amenajman planı. T.C. Orman ve Su İşleri Bakanlığı, Orman Genel Müdürlüğü, 373 s., Kastamonu.

Ayhan S., Erdoğan Ş. 2014. Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. Eskişehir Osmangazi Üniversitesi, İİBF Dergisi, 9(1):175-198.

Çölkese İ. 2009. Uzaktan algılamada ileri sınıflandırma tekniklerinin karşılaştırılması ve analizi. Yüksek Lisans Tezi, GYTE Mühendislik ve Fen Bilimleri Enstitüsü, 153 s. Gebze.

Çölkese İ., Sahin E.K., Kavzoglu T. 2016. Susceptibility mapping of shallow landslides using kernel-based Gaussian process, support vector machines and logistic regression. Journal of African Earth Sciences, 118,53-64.

Günlü A., Sivrikaya F., Başkent E.Z., Keleş S., Çakır G., Kadioğulları A.İ. 2008. Estimation of stand type parameters and land cover using Landsat-7 ETM image: a case study from Turkey, Sensors 2008, 8, 2509-2525.

Günlü A., Keleş S., Kadioğulları A.İ., Başkent E.Z. 2011. Landsat 7 ETM+ uydu görüntüsü yardımıyla arazi kullanımı, meşcere gelişim çağı ve meşcere kapallığının tahmin edilmesi; Kastamonu-Kızılcasu İşletme Şefliği örneği. I. Ulusal Akdeniz Orman ve Çevre Sempozyumu (26-28 Ekim 2011), 660-667, Kahramanmaraş, Türkiye.

Günlü A. 2012. Landsat TM uydu görüntüsü yardımıyla bazı meşcere parametreleri (gelişim çağı ve kapallılık) ve arazi kullanım sınıflarının

belirlenmesi. Kastamonu Üniversitesi, Orman Fakültesi Dergisi, 12(1):71-79.

Hsu C.W., Chang C.C., Lin C.J. 2010. A practical guide to support vector classification. National Taiwan University. <http://ntu.csie.org/~cjlin/papers/guide/guide.pdf>

Huang C., Davis L.S., Townshend J.R.G. 2002. An assessment of support vector machines for land cover classification. *International Journal of Remote Sensing*, 23(4),725-749.

Kavzoğlu T., Çölkesen İ. 2010. Destek vektör makineleri ile uydu görüntülerinin sınıflandırılmasında kernel fonksiyonlarının etkilerinin incelenmesi. *Harita Dergisi*, Temmuz 2010, 144:73-82.

Kulkarni A.D., Lowe B. 2016. Random forest algorithm for land cover classification. *Computer Science Faculty Publications and Presentations*. Paper 1. <http://hdl.handle.net/10950/341>.

Myung I.J. 2003. Tutorial on maximum likelihood estimation. *Journal of Mathematical Psychology*, 47:90–100.

Otukey J., Blaschke T. 2010. Land cover change assessment using decision trees, support vector machines and maximum likelihood classification algorithms. *Int J Appl Earth Obs Geoinf* 12:S27–S31.

Srivastava P.K., Han D., Rico-Ramirez M.A., Bray M., Islam T. 2012. Selection of classification techniques for land use/land cover change investigation. *Adv Space Res* 50(9):1250–1265.

Taati A., Sarmadian F., Mousavi A., Pour C.T.H., Shahir A.H.E. 2014. Land use classification using support vector machine and maximum likelihood algorithms by Landsat 5 TM images. *Walailak Journal of Science and Technology*, 12(8): 681-687.

Topaloğlu R.H., Sertel E., Musaoğlu N. 2016. Assessment of classification accuracies of Sentinel-2 and Landsat-8 data for land cover / use mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Volume XLI-B8, 2016, XXIII ISPRS Congress, 12–19 July 2016, Prague, Czech Republic.

Üstüner M., Şanlı F.B., Dixon B. 2015. Application of support vector machines for landuse classification using high-resolution RapidEye images: a sensitivity analysis. *European Journal of Remote Sensing*, 48: 403-422.